

# Važnost obiteljskog podrijetla i roda za uspjeh iz matematike i odabir srednje škole

BRANISLAVA BARANOVIĆ\*

IVANA JUGOVIĆ

SAŠA PUZIĆ

Institut za društvena istraživanja u Zagrebu  
Zagreb, Hrvatska

Izvorni znanstveni rad

UDK: 316.662.2-057.87:373.4

doi: 10.3935/rsp.v21i3.1174

Primljeno: rujan 2013.

*U radu su prezentirani rezultati empirijskog istraživanja koje, oslonom na Bourdiea (1977.), ispituje povezanost rodnih, socioekonomskih i sociokulturnih karakteristika učenika/ca s njihovim uspjehom iz matematike i izborom srednje škole. Istraživanje je provedeno na uzorku od 693 učenika/ca 8. razreda osnovnih škola u Gradu Zagrebu i Zagrebačkoj županiji.*

*Rezultati pokazuju da učenice imaju bolje ocjene iz matematike od učenika te da češće nego učenici namjeravaju upisati gimnazije, ali znatno rjeđe strukovne škole sa zastupljenijom matematikom (tehničke škole). Učenici/e višeg ekonomskog i kulturnog statusa postižu bolji uspjeh iz matematike i češće biraju srednje škole sa zastupljenijom nastavom matematike. Bolji uspjeh iz matematike najsnažnije predviđaju rod, obrazovanje roditelja, posjedovanje klasične literature te pristup Internetu. Pri analiziranom odabiru srednje škole, odabir gimnazije je prvenstveno objašnjen kulturnim resursima obitelji učenika/ca, dok je odabir tehničke škole više objašnjen rodom učenika/ce. Dobiveni nalazi o rodnoj i socijalnoj diferencijaciji u skladu su s nalazima istraživanja u drugim zemljama.*

**Ključne riječi:** socioekonomski status, sociokulturni status, učenici osmih razreda, uspjeh iz matematike, izbor srednje škole.

## UVOD

Matematička kompetencija postaje jedna od središnjih komponenti u razvoju ljudskog kapitala u suvremenim društvima i time sve važnija za život pojedinca (Bishop i Forgasz, 2007.). Posljedica toga je da se obrazovna postignuća iz matemati-

ke nerijetko koriste kao selektivni filter za pristup elitnim zanimanjima i privilegiranim položajima u društvu, što u konačnici povećava važnost uloge društvenih faktora za uspjeh iz matematike (Apple, 1992.; Bourdieu, 1996.).

Istraživanja utjecaja društvenih faktora na matematička postignuća ističu ulogu

\* Branislava Baranović, Institut za društvena istraživanja u Zagrebu / Institute for Social Research in Zagreb, Amruševa 11/II, 10 000 Zagreb, Hrvatska / Croatia, [baranov@idi.hr](mailto:baranov@idi.hr)

roda učenika/ce i socioekonomskog statusa učenikove/čine obitelji (Lubienski, 2008.; Wiest, 2011.). U Hrvatskoj učenici/ce iz obitelji višeg socioekonomskog statusa postižu u prosjeku bolje rezultate u školi, pa tako i u matematici, te češće upisuju gimnazije od učenika/ca iz obitelji nižeg statusa (Braš Roth i sur., 2008.; Cvitan i sur., 2011.). Dječaci postižu bolje rezultate na višim razinama matematičke pismenosti od djevojčica (Braš Roth i sur., 2008., 2010.) te čine većinu upisanih na studijima na kojima je matematika bitna (Državni zavod za statistiku, 2012.), iako djevojčice imaju bolje školske ocjene iz svih predmeta pa tako i iz matematike (Jokić i Ristić Dedić, 2010.; Jugović i sur., 2012.).

S obzirom na sve veću važnost matematičkog obrazovanja za pojedinca i društvo (Bishop i Forgasz, 2007.; Puzić i Baranović, 2012.), opisane razlike u postignućima iz matematike mogu predstavljati ozbiljne zapreke u obrazovnim i profesionalnim karijerama značajnog broja učenika/ca. Ovakva situacija upućuje na potrebu za istraživanjem rodni i društvenih karakteristika matematičkih postignuća, posebice u Hrvatskoj gdje su takva istraživanja rijetka. Ovaj rad bavi se istraživanjem povezanosti rodni, socioekonomskih i sociokulturnih karakteristika učenika/ca s njihovim uspjehom iz matematike i izborom srednje škole.

### **DRUŠTVENA OBILJEŽJA UČENIKA/CA I USPJEH IZ MATEMATIKE**

U istraživanjima društvenih aspekata obrazovanja obiteljsko se podrijetlo najčešće operacionalizira uz pomoć obiteljskog socioekonomskog statusa (SES) definirano kao »relativan položaj (...) unutar društvene hijerarhije ovisno o pristupu ili raspoloživosti financijskih sredstava, moći i društvenog prestiža« (Sirin, 2005.: 418).

Ovakva se definicija veže uz tripartitnu operacionalizaciju SES-a u kojoj se kao najvažniji prediktori obrazovnog uspjeha ispituju obiteljski prihodi te obrazovanje i zanimanje roditelja koji indiciraju u kojoj su mjeri učeniku/ci dostupni materijalni resursi potrebni za uspjeh u školi (Baumert i Schümer, 2001.).

Razlike u obiteljskom SES-u povezane su i s razlikama u kulturnom kapitalu učenika/ca pod čime se misli na kulturne resurse učenika/ca i njihovih roditelja koje škola prepoznaje kao vrijedne (Lareau i Weininger, 2003.). Prema Bourdieu (1997.), kulturni kapital odnosi se na posjedovanje jezičnih kompetencija i kulturnih sklonosti (utjelovljeni kulturni kapital), posjedovanje kulturnih dobara (objektivirani kulturni kapital) te obrazovanje roditelja (institucionalizirani kulturni kapital). On također naglašava važnost ekonomskog kapitala (posjedovanje novca i materijalnih dobara), socijalnog kapitala (društvenu umreženost) i pripadnost pojedinca određenoj društvenoj klasi čiji način života utječe na djelovanje pojedinaca (habitus) i njihova obrazovna postignuća. Bourdieu (1977.) smatra da pojedinci posjeduju različite količine ekonomskog, kulturnog i socijalnog kapitala pri čemu obrazovni sustavi i obrazovne institucije svojom strukturom i praksom nagrađuju, tj. privilegiraju učenike i učenice s većim ekonomskim, kulturnim i socijalnim kapitalom.

U istraživanjima obrazovnih postignuća kulturni kapital učenika/ca u pravilu se operacionalizira na temelju niza indikatora obiteljskog socijalizacijskog okruženja, a koji uključuju obrazovanje roditelja, posjedovanje knjiga i drugih kulturnih dobara, participaciju u aktivnostima visoke kulture, obiteljske čitalačke navike ili literarne preferencije (Sullivan, 2001.; Flere i sur., 2010.). Iz navedenog je vidljivo da se pojedini indikatori kulturnog kapitala učenika/

ca preklapaju s tradicionalnim indikatorima obiteljskog SES-a, prvenstveno s obrazovanjem roditelja i posjedovanjem obrazovnih dobara (White, 1982.). Na koji se način navedeni indikatori društvenog podrijetla učenika/ca koriste u istraživanjima obrazovnih nejednakosti ovisi o teorijskom okviru konkretnog istraživanja (Karabel i Halsey, 1977.).

Premda razmatrana povezanost socioekonomskog statusa (SES) i kulturnih resursa, odnosno kulturnog kapitala s uspjehom u školi nalazi svoju potvrdu u rezultatima brojnih studija (Baumert i Schümer, 2001.; Sullivan, 2001.), specifičan efekt SES-a te posebice kulturnog kapitala na postignuća iz matematike razmjerno je manje istražen, a rezultati nisu jednoznačni (Tate, 1997.; Jungbauer-Gans, 2006.; Lubienski, 2008.).

U metaanalizi efekata socioekonomskog statusa na rješavanje različitih vrsta školskih testova, White (1982.) navodi prosječnu korelaciju SES-a i postignuća iz matematike od  $r = 0,20$ , što je slično korelaciji SES-a i verbalnog postignuća ( $r = 0,23$ ). Metaanalize ukazuju da je socioekonomski status roditelja značajno povezan s matematičkim postignućima u školi te da se ovaj efekt povećava s godinama školovanja učenika/ca (Sirin, 2005.). U istraživanjima u kojima su se koristile višedimenzionalne mjere SES-a pokazalo se da svaka od tradicionalnih SES komponenti (obrazovanje i zanimanje roditelja, obiteljski prihod) zadržava nezavisne (statistički značajne) efekte na matematička postignuća učenika/ca (Crane, 1996.). Na značajnu ulogu obiteljskog SES-a u postizanju uspjeha iz matematike upućuju i podaci međunarodnog PISA istraživanja (OECD, 2004.). U zemljama OECD-a je između 14% i 17% varijance učeničkih postignuća iz matematike bilo objašnjeno PISA indeksom ekonomskog, društvenog i kulturnog statusa (ESCS) (OECD, 2004., 2007.). Analiza hr-

vatskih PISA rezultata pokazala je da bolji rezultat iz matematičke pismenosti imaju učenici/ce iz obitelji s višim HISEI (Najviši međunarodni socioekonomski indeks zanimanja) i ESCS indeksom (indeksi koji mjere socioekonomski status učenika/ca) te s većim brojem knjiga u kućanstvu i više kulturnih dobara, kao i oni s boljim uvjetima za učenje kod kuće (Braš Roth i sur., 2008.: 159).

Iako gornja rasprava pokazuje da rezultati istraživanja velikim dijelom ovise o korištenim varijablama i njihovoj operacionalizaciji, većina istraživačkih nalaza upućuje na značajnu povezanost socioekonomskog i sociokulturnog statusa učenika i postignuća iz matematike (usp. Tate, 1997.).

### **DRUŠTVENA OBILJEŽJA UČENIKA/CA I ODABIR SREDNJE ŠKOLE**

Društvena obilježja učenika/ca također su povezana i s njihovim obrazovnim aspiracijama i odabirom srednje škole (Baumert i Schümer, 2001.). S obzirom na činjenicu da matematička kompetencija postaje sve važnija za pozicioniranje pojedinaca na tržištu rada (Carnevale i Desrochers, 2003.), mogu se očekivati značajni efekti obiteljskog ekonomskog i kulturnog kapitala na odabir srednje škole s većom ili manjom zastupljenošću matematike. Pritom valja naglasiti da su matematički sadržaji tradicionalno najzastupljeniji u akademski usmjerenim gimnazijama, nešto manje u tehničkim školama, a najmanje u industrijskim i obrtničkim strukovnim školama (Popkewitz, 1988.; Braš Roth i sur., 2008.).

Razmatrajući različite prediktore odabira srednje škole na uzorku srednjoškola u Njemačkoj, de Graaf (1988.) ističe da je odluka o tome hoće li se školovanje nastaviti u gimnazijskom (akademskom)

tipu obrazovanja u većoj mjeri povezana s kulturnim resursima obitelji, dok je odabir između pojedinih neakademske smjerova više odraz financijskih prilika unutar obitelji. Osim individualnih sposobnosti učenika/ca (ocjene iz matematike i njemačkog jezika), utvrđeni su efekti obiteljske čitalačke klime na odabir gimnazija, te obiteljskih financijskih resursa na odabir srednjih strukovnih škola. Na temelju danskih PISA rezultata pokazalo se da pozitivne efekte na vjerojatnost odabira akademski usmjerene srednje škole naspram strukovnih škola, pored akademske sposobnosti učenika/ca, imaju socioekonomski status obitelji, obrazovanje očeva i kulturni kapital učenika/ca iskazan kroz posjedovanje kulturnih dobara, participaciju u kulturnim aktivnostima (posjeti muzeju, kazalištu i koncertima) i kulturnu komunikaciju u obitelji (razgovori o političkim, društvenim i kulturnim temama) (Meier Jaeger, 2009.). Autor posebno izdvaja važnost obiteljskog kulturnog kapitala, koji u egalitarno obojenom danskom kontekstu u kojem se smanjuju ekonomske zapreke obrazovanju, često ima ključnu ulogu. Istražujući slovenske srednjoškolske Flere i sur. (2010.: 53) također navode pozitivan efekt obiteljskog kulturnog kapitala (obrazovanje roditelja, participacija u kulturnim aktivnostima) na odabir gimnazija, dok se ekonomski status obitelji učenika/ca nije pokazao statistički značajnim prediktorom odabira srednje škole. U Hrvatskoj, usporedivih analiza nema, ali podaci hrvatskog Eurostudent istraživanja pokazuju da je među studentima/cama čiji roditelji imaju visoko obrazovanje najviše onih koji su završili gimnaziju (njih 70%), dok je među učenicima/cama čiji roditelji imaju niži stupanj obrazovanja najveći broj završio srednju strukovnu školu (njih 80%) (Cvitan i sur., 2011.: 39). Premda navedena istraživanja ne specificiraju povezanost socioekonomskih i sociokulturnih karakte-

ristika učenika/ca s izborom srednjih škola s više ili manje matematike, ona indirektno ukazuju na ovu povezanost zbog razmjerno veće zastupljenosti matematike u gimnazijama naspram strukovnih škola.

### **POVEZANOST RODA S USPJEHOM IZ MATEMATIKE I ODABIROM ŠKOLE**

Prije tridesetak godina većina istraživanja pokazivala je da su dječaci uspješniji u matematici od djevojčica, no novija istraživanja ukazuju da se rodne razlike u matematičkom postignuću smanjuju, da ne postoje ili da se okreću u korist djevojčica (Hyde i sur., 1990.b; Mullis i sur., 2004.; Farmer i sur., 1995.; Lindberg, Hyde, Petersen i Linn, 2010.). Wiest (2011.) ističe da uspješnost dječaka i djevojčica varira ovisno o mjeri školskih postignuća (školske ocjene ili standardizirani testovi) i razini obrazovanja na kojoj se ispituje (osnovna ili srednja škola). Ukoliko se postignuće iz matematike iskazuje školskim ocjenama, djevojčice su uspješnije od dječaka na osnovnoškolskoj i srednjoškolskoj razini (Hart Reyes i Stanic, 1988.; Hyde i sur., 1990.a). Kada se kao mjera postignuća iz matematike koriste standardizirani testovi znanja, rezultati su nekonzistentni i većinom pokazuju da dječaci postižu više rezultate od djevojčica ili da razlika nema. Rezultati istraživanja također variraju među zemljama, pa su tako dječaci postigli bolje rezultate od djevojčica u PISA istraživanju u 35 zemalja, u 5 zemalja su djevojčice bile bolje, a u 25 zemalja nije bilo statistički značajnih rodni razlika u postignuću iz matematike (Braš Roth i sur., 2010.: 197).

Nalaze da djevojčice imaju bolje ocjene od dječaka iz matematike, ali i iz većine drugih školskih predmeta Wiest (2011.) objašnjava time što su djevojčice svojim ponašanjem bolje prilagođene zahtjevima

škole: redovitije su u nastavi ili savjesnije u ispunjavanju domaćih zadataka, kao i općenito više disciplinirane i motivirane za uspjeh. U tom smislu, više ocjene djevojčica odražavaju i primjereno školsko ponašanje koje do određene mjere može »maskirati« samo matematičko postignuće. Dublje razumijevanje ove problematike pružaju istraživanja koja ukazuju na to da je visok školski uspjeh dio dominantne konstrukcije femininosti kod djevojaka (Walkerline i sur., 2001.), dok mladići svoju maskulinitet izgrađuju kroz stav da učenje nije »cool«, odnosno da se školski uspjeh treba postići bez truda i učenja (Jackson i Dempster, 2009.). Na ovaj način rodni identiteti mogli bi doprinijeti boljem školskom uspjehu kod djevojaka, budući da se od djevojaka očekuje da budu uspješne u školi, dok očekivanje da mladići ne uče (i pritom postižu uspjeh) može doprinijeti tome da se oni manje trude te da ne postižu visok školski uspjeh.

Rodne razlike još uvijek postoje u odabirima srednjih škola, studija i karijera, posebice u području tehničkih znanosti u kojima je poznavanje matematike od velike važnosti (Eccles, 1994.; Moreau i sur., 2008.). Primjerice, u Hrvatskoj je postotak djevojaka u odnosu na mladiće značajno veći u srednjim umjetničkim školama (69,9%) i gimnazijama (62,6%) te značajno manji u industrijskim i obrtničkim školama (34,9%) (Državni zavod za statistiku, 2012.: 28). U kategoriji tehničkih i srodnih škola omjer djevojaka i mladića je podjednak (49,8% djevojaka i 50,2% mladića), no neke škole mogu se smatrati stereotipno muškima s obzirom na nizak udio djevojaka, kao što su škole u području strojarstva i brodogradnje (4,8% djevojaka), elektro-

tehnike (5,1%) i graditeljstva (22%), dok se neke škole mogu smatrati stereotipno ženskim poput onih u području ekonomije (69,5% djevojaka) i zdravstva (75,8% djevojaka) (Državni zavod za statistiku, 2008.). Prema Baranović (2011.), tradicionalna slika o rodnoj dihotomizaciji obrazovanja postaje jasno vidljiva upravo na razini srednjeg obrazovanja jer je to vrijeme kada prestaje obavezno obrazovanje i kada učenici/ce donose odluke o budućem obrazovnom i profesionalnom putu.

Čimbenici kojima se pokušalo objasniti zašto su mladići uspješniji u matematici od djevojaka i zašto u većoj mjeri biraju obrazovne i karijerne putove za koje je važna matematika su: viša motivacija za matematiku kod mladića, posebice procjena vlastite kompetencije i očekivanje uspjeha u matematici (Lupart i sur., 2004.), veća podrška socijalne okoline mladićima za bavljenje matematikom (Jacobs i Eccles, 1992.) i nesklad između ženske rodne uloge i predožbe o matematici (Massey, 1995.). No, istraživanja također ukazuju da djevojke i mladići podjednako vole matematiku i smatraju da je matematika uzbudljiva, korisna, važna, zanimljiva, razumljiva i teška (Eccles i sur., 1993.; Marušić, 2006.), kao i to da učenici/e ne stereotipiraju matematiku kao mušku domenu (Arambašić i sur., 2005.), što je u skladu sa spoznajom da se rodne razlike u matematičkom uspjehu smanjuju, čak i na standardiziranim testovima (Scafidi i Bui, 2010.; Hyde i sur., 2008.).

## CILJEVI, ISTRAŽIVAČKI PROBLEMI I HIPOTEZE

Cilj ovog istraživanja<sup>1</sup> bio je ispitati vezu roda, socioekonomskih i sociokul-

<sup>1</sup> Prezentirani podaci predstavljaju dio šireg istraživanja o poučavanju i učenju temeljnih kompetencija za život i rad u društvu znanja, uključujući i matematičku kompetenciju, u osnovnim školama u Hrvatskoj. Projekt je financiralo Ministarstvo znanosti, obrazovanja i sporta RH (Broj projekta: 100-1001677-0938).



turnih obilježja učenika/ca s: a) njihovim školskim uspjehom iz matematike i b) njihovim odabirom srednje škole (gimnazije, tehničke škole sa zastupljenijom matematikom<sup>2</sup> te ostalih strukovnih škola).

Osnovni istraživački problemi na koje smo istraživanjem nastojali odgovoriti bili su: 1) ispitati pojedinačne efekte roda i osnovnih obilježja ekonomskog i kulturnog statusa učenika/ca na njihov školski uspjeh iz matematike te na njihovu odluku da upišu gimnaziju, tehničku školu sa zastupljenijom matematikom ili neku od ostalih strukovnih škola, 2) ispitati koje od navedenih varijabli najbolje predviđaju školski uspjeh učenika/ca iz matematike te koje od njih, uključujući i ocjenu iz matematike, predviđaju njihov izbor gimnazije, tehničke škole sa zastupljenijom matematikom i ostalih strukovnih škola.

Pretpostavili smo da će učenici/ce s višim socioekonomskim i sociokulturnim statusom imati bolji uspjeh iz matematike te da će češće birati srednje škole sa zastupljenijom nastavom matematike (prvenstveno gimnazije i prestižnije tehničke škole sa sličnom satnicom nastave matematike) nego strukovne škole u kojima je matematika zastupljena u manjoj mjeri (ostale 4-godišnje strukovne škole i 3-godišnje strukovne škole) što je u skladu s prethodno provedenim istraživanjima (De Graaff, 1988.; Bourdieu, 1996.; Sirin, 2005.; Jungbauer-Gans, 2006.; Meier Jaeger, 2009.).

Istraživački nalazi o povezanosti roda i uspješnosti u matematici su raznoliki, ovi-

sno o dobi ispitanika/ca, razini obrazovanja te o tome je li riječ o školskom uspjehu ili uspjehu u rješavanju standardiziranih testova (Hart Reyes i Stanic, 1988.; Hyde i sur., 1990.a; Wiest, 2011.). Kako se u našem istraživanju radi o osnovnoj školi i školskom uspjehu iz matematike, pošli smo od pretpostavke da će učenice imati bolja matematička postignuća od učenika, te da će učenice u većoj mjeri birati gimnazije, a učenici tehničke škole u kojima je matematika više zastupljena.

## METODE

### Uzorak i postupak

Istraživanje je provedeno 2010. godine na uzorku od 693 učenika/ca 8. razreda osnovnih škola u Gradu Zagrebu i Zagrebačkoj županiji. Uzorak je bio stratificiran prema veličini škole (broj učenika/ca) i ruralno-urbanoj lociranosti škola te reprezentativan na razini Grada Zagreba i Zagrebačke županije. Od ukupno 136 osnovnih škola, uzorkom je obuhvaćeno 36 škola (23%). U uzorku je bilo 355 djevojčica (51,2%), 322 dječaka (46,5%) i 16 osoba (2,3%) koje nisu označile spol<sup>3</sup>. Oko 25% ispitanika/ca imalo je roditelje sa završenom visokom i višom školom (majke 25,7%, očevi 24,3%), oko 50% imalo je roditelje sa završenom srednjom školom (majke 48,7%, očevi 51%), a 8,1% ispitanika/ca imalo je majku te 3,8% oca koji nisu završili osnovnu školu. Oko 20% ispitanika/ca nije znalo koju završenu razinu obrazovanja imaju njihovi roditelji (za majke 17,5%, za oče-

<sup>2</sup> Kategorija tehničke škole sa zastupljenijom matematikom uključuje srednjoškolske programe s najmanje 4 sati matematike tjedno. Npr. smjerovi arhitektonski tehničar ili građevinski tehničar u Graditeljskoj tehničkoj školi u Zagrebu ([http://ss-graditeljska-zg.skole.hr/smjeroi/arhitektonski\\_tehni\\_ar](http://ss-graditeljska-zg.skole.hr/smjeroi/arhitektonski_tehni_ar)).

<sup>3</sup> Učenici/e kojima nedostaju podaci za varijablu spol isključeni su iz analiza u kojima je korištena ta varijabla.

ve 20,9%)<sup>4</sup>. Kada je riječ o radnom statusu roditelja, pokazalo se da 79,1% ispitanika/ca ima majku koja je zaposlena, 18,2% majku koja je nezaposlena, a 2,8% majku koja je umirovljenica te da je otac 86,2% ispitanika/ca zaposlen, 7,9% nezaposlen, a od 5,9% ispitanika/ca umirovljenik/ca. Podaci su prikupljeni anketnim upitnikom. Anketiranje je bilo grupno (provedeno je u razredu za vrijeme nastave), dobrovoljno i anonimno, a trajalo je u prosjeku jedan školski sat. Upitnik su ispunjavali učenici/ce za koje je dobivena pismena suglasnost roditelja.

### Instrumenti

Instrumenti korišteni u istraživanju testirani su u predistraživanju na učenicima/cama osmih razreda iz pet osnovnih škola iz centra i prigradskih naselja Zagreba (N=107). U svakoj je školi istraživanje provedeno s učenicima jednog osmog razreda. Popunjavanje upitnika trajalo je jedan školski sat. Cilj predistraživanja bio je testirati jasnoću pitanja učenicima/ama i procijeniti vrijeme potrebno za popunjavanje upitnika. Učenici/e su bili zamoljeni da tijekom predistraživanja daju primjedbe i komentare na sadržaj upitnika i razumljivost pitanja. Na temelju analize rezultata i komentara učenika/ca pojedina pitanja su preoblikovana.

Obrazovno postignuće u upitniku je operacionalizirano pitanjem o ocjeni iz matematike na polugodištu osmog razreda.

Namjera odabira vrste srednje škole operacionalizirana je pitanjem: »Ako si odabrao vrstu srednje škole u kojoj ćeš na-

staviti školovanje, koju vrstu srednje škole i koji smjer bi htio/htjela upisati?« Odgovori učenika/ca naknadno su kategorizirani kao odabir gimnazije, tehničke škole sa zastupljenijom matematikom (škole koje imaju najmanje 4 sata nastave matematike tjedno) te ostale strukovne škole.

Iz pregleda literature vidljivo je da su socioekonomski i sociokulturni status u istraživanjima različito konceptualizirani i operacionalizirani, odnosno iskazani kroz različite indikatore. Tako je npr. u nekim istraživanjima socioekonomski status mjeren kroz prihod, obrazovanje i zanimanje (White, 1982.; Crane 1996.; Sirin, 2005.). Za razliku od navedenih autora, Bourdieu (1977., 1997.) obrazovanje smatra indikatorom kulturnog kapitala. Socioekonomski i sociokulturni status učenika/ca u našem je istraživanju operacionaliziran oslonom na Bourdieuove koncepte ekonomskog i kulturnog kapitala.

Ekonomski kapital učenika/ca ispitan je pomoću 6 pitanja o posjedovanju materijalnih dobara koja mogu biti relevantna za obrazovna postignuća učenika/ca te radnom statusu i zanimanju roditelja učenika/ca. Posjedovanje dobara operacionalizirano je pitanjem: »Imaš li kod kuće:« računalo (prijenosno ili stolno), pristup internetu, kablovsku ili satelitsku televiziju (1 – »ne«, 2 – »da«) te vlastiti stol za učenje? (1 – »nemam«, 2 – »imam vlastiti stol za kojim radim sam«, 3 – »dijelim stol s drugima«). Zanimanje i radni status oca i majke učenika/ca ispitan su kao indikatori financijskog statusa obitelji učenika/ca. Radni status roditelja mjeren je pitanjem »Tvoja majka/

<sup>4</sup> Ti učenici/e isključeni su iz hijerarhijskih regresijskih analiza, ali su se neki od njih našli u ostalim analizama u kojima su obrazovanje oca i majke spojeni u jednu varijablu. Primjerice, kada je formiran zajednički rezultat za završeni stupanj obrazovanja oba roditelja, pokazalo se da 2,9% učenika/ca ima roditelje koji jesu završili ili nisu završili osnovnu školu, zatim 50,4% učenika/ca ima barem jednog roditelja sa završenom srednjom školom, a 33,5% učenika/ca ima barem jednog roditelja sa završenim fakultetom ili višom školom. Preostalih 13,3% učenika/ca nije imalo podatke niti za jednog roditelja te je isključeno iz daljnjih analiza.

tvoj otac je trenutno:« 1 – »zaposlen/a«, 2- »nezaposlen/a«, 3 – »umirovljenik/ca«. Zanimanje roditelja ispitano je pitanjima otvorenog tipa na koje su učenici/e odgovarali upisivanjem zanimanja majke i oca, no uslijed nedovoljne pouzdanosti učeničkih odgovora ova varijabla nije korištena u obradi.

U konceptualizaciji kulturnog kapitala naglasak je stavljen na objektivirani i institucionalizirani kulturni kapital. Objektivirani kulturni kapital operacionaliziran je pitanjima posjeduje li obitelj učenika/ce klasičnu i stručnu literaturu. Pitanja su glasila: »Imaš li kod kuće knjige klasične literature (npr. književna djela)?« i »Imaš li kod kuće stručne knjige (npr. iz tehnike)?« Na pitanja se odgovaralo samo s »ne« i »da« odgovorima. Institucionalizirani kulturni kapital ispitan je pitanjem o najvišem završenom stupnju obrazovanja majke i oca s odgovorima od 7 stupnjeva (1 – »nezavršena osnovna škola« do 7 – »magisterij ili doktorat«).

## REZULTATI

U tablici 1. prikazani su rezultati t-testova, analiza varijance i hi-kvadrat testova za ispitivanje razlika u školskom uspjehu iz matematike na polugodištu 8. razreda i razlika u namjeri odabira vrste srednje škole s obzirom na rod te već spomenute indikatore kulturnog i ekonomskog kapitala<sup>5</sup>.

Rezultati t-testa pokazuju da učenice imaju statistički značajno bolji školski uspjeh iz matematike od učenika. Učenici u prosjeku imaju ocjenu »dobar«, a učenice »vrlo dobar«. Rodne razlike u odabiru škole također su statistički značajne pri čemu više učenica (54,9%) nego učenika (38,9%) planira upisati gimnazije, dok tehničke škole sa zastupljenijom matematikom planira upisati samo 1% učenica i 19,7% učenika. Podjednak postotak učenika i učenica planira upisati ostale strukovne škole (oko 40%).

Rezultati analize varijance pokazuju da postoje statistički značajne razlike u ocjenama iz matematike s obzirom na obrazovanje roditelja te da se sve tri skupine međusobno razlikuju, pri čemu je uspjeh učenika/ca iz matematike viši što im roditelji imaju viši završeni stupanj obrazovanja. Učenici/e čija oba roditelja imaju osnovnu školu kao najviši završeni stupanj obrazovanja imaju iz matematike u prosjeku ocjenu »dovoljan«, učenici/e čiji je barem jedan roditelj završio srednju školu ocjenu »dobar«, a učenici/e čiji je barem jedan roditelj završio višu školu ili fakultet »vrlo dobar«. Stupanj obrazovanja roditelja povezan je i s odabirom srednje škole, a za to su najviše odgovorna razlikovanja u odabiru gimnazija i strukovnih škola s manje zastupljenom matematikom, a najmanje razlikovanja u odabiru tehničkih škola sa zastupljenijom matematikom. Primjerice, samo 7,7% učenika/ca čija oba roditelja imaju (ne)završenu osnovnu školu planira upisati gimnaziju, dok isto planira 34,8% učenika/ca s barem jednim srednjoškolski

<sup>5</sup> Ispitivanje razlika s obzirom na posjedovanje računala nije bilo moguće zbog vrlo malog broja ispitanika/ca koji nemaju računalo (2,7%). Zbog malog broja ispitanika/ca koji kod kuće nemaju stol za učenje (1,7%), za potrebe analiza spojene su kategorije ispitanika/ca koji stol dijele s drugima i onih koji ga nemaju. Zbog malog broja ispitanika/ca s umirovljenima ocem (5,9%) i majkom (2,8%), te skupine su za potrebe analiza spojene sa skupinama ispitanika/ca čiji su roditelji nezaposleni.



Tablica 1.

Razlike u ocjeni iz matematike i odabiru srednje škole s obzirom na rod te indikatore kulturnog i socijalnog kapitala

	Ocjena iz matematike				Odabir srednje škole (%)			
	M	SD	t-test ili ANOVA	Post hoc testovi	Gimnazija	Tehnička škola sa zastupljenijom matematičkom	Ostale strukovne škole	$\chi^2$ test
Ukupni uzorak	3,43	1,219			48,5	9,0	42,5	
<i>Rod</i>								
Ženski	3,65	1,183	t(672)=4,88***		54,9	1,0	44,1	$\chi^2(2)=53,47***$
Muški	3,19	1,216			38,9	19,7	41,4	
<i>Obrazovanje roditelja</i>								
Osnovna škola	2,35	0,813	F(2/597)=39,88***	1-2**, 1-3***, 2-3***	7,7	7,7	84,6	$\chi^2(4)=81,4674***$
Srednja škola	3,23	1,221			34,8	11,7	53,5	
Fakultet i viša škola	3,98	1,050			75,1	5,4	19,5	
<i>Literatura</i>								
Niti klasična niti stručna	2,77	1,082	F(3/669)=19,24***	1-3*, 1-4***, 3-4***	11,9	15,3	72,9	$\chi^2(6)=43,76***$
Samo stručna	3,39	1,321			38,7	9,7	51,6	
Samo klasična	3,23	1,302			47,9	7,4	44,6	
Klasična i stručna	3,71	1,109			57,9	8,6	33,6	
<i>Radni status majke</i>								
Zaposlena	3,49	1,210	t(683)=2,45*		52,0	7,7	40,3	$\chi^2(2)=11,20**$
Nezaposlena/umirovljenica	3,21	1,202			34,4	15,1	50,5	
<i>Radni status oca</i>								
Zaposlen	3,47	1,214	t(669)=2,43*		49,9	9,3	40,9	$\chi^2(2)=4,15$
Nezaposlen/umirovljenik	3,14	1,157			37,3	9,0	53,7	
<i>Internet</i>								
Ima	3,54	1,181	t(80,70)=8,77***		52,0	9,4	38,6	$\chi^2(2)=30,30***$
Nema	2,33	1,040			10,5	5,3	84,2	
<i>Satelitska TV</i>								
Ima	3,40	1,233	t(684)=-1,37		49,8	8,9	41,4	$\chi^2(2)=1,42$
Nema	3,58	1,141			42,5	10,0	47,5	
<i>Vlastiti stol</i>								
Ima vlastiti stol	3,47	1,217	t(687)=2,18*		50,7	9,2	40,2	$\chi^2(2)=9,84**$
Nema/dijeli stol s drugima	3,13	1,175			29,4	7,8	62,7	

\* p<0,05, \*\* p<0,01, \*\*\* p<0,001

obrazovanim roditeljem i 75,1% učenika/ca s barem jednim visoko obrazovanim roditeljem.

Razlike u ocjeni iz matematike s obzirom na posjedovanje klasične i/ili stručne literature također su statistički značajne.

Učenici/e koji kod kuće nemaju niti klasičnu niti stručnu literaturu imaju lošiju ocjenu od onih koji imaju samo klasičnu literaturu i onih koji imaju obje vrste literature. Također se pokazalo da učenici/e koji posjeduju samo klasičnu literaturu imaju lošiji uspjeh

od onih koji posjeduju i klasičnu i stručnu literaturu. Posjedovanje literature također je bilo povezano s odabirom srednje škole – gimnazije su najviše birali učenici/e koji kod kuće imaju obje vrste literature, tehničke škole sa zastupljenijom matematikom podjednako su birali učenici/e iz sve četiri skupine s obzirom na posjedovanje literature, dok su ostale srednje škole najviše birali učenici koji kod kuće nemaju niti klasičnu niti stručnu literaturu.

Rezultati su pokazali da se učenici/e statistički značajno razlikuju u ocjeni iz matematike s obzirom na posjedovanje pristupa internetu, posjedovanje vlastitog stola za učenje te radni status majke i oca, ali da se ne razlikuju s obzirom na posjedovanje satelitske televizije. Kao što se i očekivalo, učenici/e koji imaju pristup internetu i vlastiti stol za učenje, kao i oni kojima su majka i otac zaposleni, imaju bolje ocjene iz matematike od onih koji nemaju te elemente ekonomskog kapitala. Nadalje, odabir srednje škole bio je povezan s posjedovanjem pristupa internetu, posjedovanjem vlastitog stola za učenje i radnim statusom majke, dok nije bio povezan s radnim statusom oca i s posjedovanjem satelitske televizije. U skladu s očekivanjima, učenici/e koji imaju pristup internetu i vlastiti stol te čija je majka zaposlena češće odabiru gimnazije nego strukovne škole s manje zastupljenom matematikom u odnosu na one koji to nemaju. Razlike s obzirom na navedene elemente ekonomskog kapitala nisu bile velike kada je riječ o odabiru tehničkih škola sa zastupljenijom matematikom.

Osim ispitivanja pojedinačnih efekata roda i elemenata kulturnog i ekonomskog kapitala, željelo se ispitati i koje su od tih varijabli najsnažniji prediktori ocjene iz matematike i odabira vrste srednje škole. Hijerarhijska regresijska analiza za objašnjenje uspjeha iz matematike na cijelom uzorku provedena je u pet koraka kako bi se

ispitalo koliko dodatne varijance objašnjava svaki blok prediktora. U prvom koraku uvrštena je varijabla rod, u drugom i trećem indikator kulturnog kapitala (obrazovanje roditelja, posjedovanje knjiga), a u četvrtom i petom koraku indikator ekonomskog kapitala (radni status roditelja, posjedovanje pristupa internetu i posjedovanje vlastitog stola za učenje). Redoslijed uvrštavanja varijabli kulturnog i ekonomskog kapitala u hijerarhijsku regresijsku analizu vođen je rezultatima empirijskih istraživanja (npr. Jungbauer-Gans, 2006.; Flere i sur., 2010.) prema kojima kulturni kapital učenika u većoj mjeri doprinosi objašnjenju njihova obrazovnog uspjeha od ekonomskog kapitala. Iz regresijske analize izuzeta je varijabla koja nije imala značajan efekt na ocjenu (posjedovanje satelitske/kablovske televizije). Također su provedene zasebne hijerarhijske regresijske analize za učenice i učenike s istim prediktorima kao i na cijelom uzorku, izuzev varijable rod. Prvo su provjereni Pearsonovi koeficijenti korelacije ocjene iz matematike s potencijalnim prediktorima, koji su u tablici 2. prikazani zasebno za učenice i učenike, nakon čega su provedene hijerarhijske regresijske analize prikazane u tablici 3.

Tablica 2.  
Korelacije ocjene iz matematike s potencijalnim prediktorima<sup>a</sup>

	Ocjena iz matematike	Obrazovanje majke	Obrazovanje oca	Klasična literatura	Stručna literatura	Radni status majke	Radni status oca	Internet	Vlastiti stol
Ocjena iz matematike	-	0,365***	0,344***	-0,206***	-0,268***	-0,118*	-0,142**	-0,317***	0,000
Obrazovanje majke	0,254***	-	0,499***	-0,347***	-0,347***	-0,350***	-0,054	-0,244***	-0,081
Obrazovanje oca	0,258***	0,528***	-	-0,202**	-0,229***	-0,138*	-0,194**	-0,235***	-0,046
Klasična literatura	-0,179**	-0,143*	-0,136*	-	0,332***	0,201***	0,026	0,252***	-0,018
Stručna literatura	-0,233***	-0,216***	-0,238***	0,330***	-	0,135*	0,061	0,208***	-0,006
Radni status majke	-0,059	-0,300***	-0,215***	0,059	0,214***	-	0,042	0,120*	0,039
Radni status oca	-0,056	-0,146*	-0,105	0,041	0,073	0,058	-	0,034	0,033
Internet	-0,275***	-0,193**	-0,225***	0,173**	0,240***	0,122*	0,142*	-	0,000
Vlastiti stol	-0,150**	-0,159*	-0,193**	0,065	0,094	0,062	0,109	0,086	-

\* p<0,05, \*\* p<0,01, \*\*\* p<0,001

<sup>a</sup> Iznad dijagonale su prikazani Pearsonovi koeficijenti korelacije na uzorku učenika, a ispod dijagonale na uzorku učenika.

Kod učenica ocjena iz matematike ima umjerene statistički značajne korelacije s obrazovanjem majke ( $p=0,365$ ;  $p<0,001$ ), obrazovanjem oca ( $p=0,344$ ;  $p<0,001$ ), te pristupom internetu ( $p=-0,317$ ;  $p<0,001$ ), dok su ostale korelacije ocjene iz matematike s potencijalnim prediktorskim varijablama manje od 0,3. Kod učenika su sve korelacije ocjene iz matematike s potencijalnim prediktorima niže od 0,3, no također se kao najviše mogu izdvojiti one s obrazovanjem majke ( $p=0,254$ ;  $p<0,001$ ), obrazovanjem oca ( $p=0,258$ ;  $p<0,001$ ) i pristupom internetu ( $p=-0,275$ ;  $p<0,001$ ). Smjer povezanosti upućuje na to da bolje ocjene imaju učenici/e čiji su roditelji obrazovani, te koji kod kuće imaju pristup internetu. Najveće su pozitivne korelacije između obrazovanja oca i majke, i na uzorku učenica ( $p=0,499$ ;  $p<0,001$ ), i na uzorku učenika

( $p=0,528$ ;  $p<0,001$ ). Također se može primijetiti da kod učenica obrazovanje majke ima statistički značajne umjerene korelacije s posjedovanjem klasične ( $p=-0,347$ ;  $p<0,001$ ) i stručne literature ( $p=-0,347$ ;  $p<0,001$ ), te radnim statusom majke ( $p=-0,350$ ;  $p<0,001$ ), dok su kod mladića sve te povezanosti niske (iako također statistički značajne). Može se primijetiti da je više obrazovanje majki povezano s posjedovanjem klasične i stručne literature, te da obrazovanje majke imaju veće šanse biti zaposlene od niže obrazovanih majki. Sličan obrazac vidljiv je i kod korelacija navedenih varijabli s obrazovanjem oca, samo što su koeficijenti korelacija niži nego u slučaju obrazovanja majke.

U tablici 3. prikazani su rezultati hijerarhijske regresijske analize za objašnjenje ocjene iz matematike na cijelom uzorku, te zasebno za djevojčice i dječake.

Tablica 3.

*Hijerarhijska regresijska analiza za objašnjenje uspjeha iz matematike na cijelom uzorku (N=479) te za učenice (N=244) i učenike (N=235) zasebno*

Blokovi prediktora	Cijeli uzorak		Djevojčice		Dječaci	
	$\Delta R^2$	B	$\Delta R^2$	$\beta$	$\Delta R^2$	$\beta$
Rod	0,034***		–		–	
Rod		-0,184***		–		–
Obrazovanje roditelja	0,117***		0,169***		0,081***	
Rod		-0,186***		–		–
Obrazovanje majke		0,233***		0,276***		0,198**
Obrazovanje oca		0,161**		0,199**		0,126
Posjedovanje knjiga	0,019**		0,032*		0,009	
Rod		-0,182***		–		–
Obrazovanje majke		0,190***		0,193**		0,182*
Obrazovanje oca		0,150**		0,193**		0,114
Klasična literatura		-0,119**		-0,164*		-0,080
Stručna literatura		-0,054		-0,065		-0,039
Radni status roditelja	0,001		0,002		0,001	
Rod		-0,182***		–		–
Obrazovanje majke		0,191***		0,192*		0,189*
Obrazovanje oca		0,147**		0,186**		0,114
Klasična literatura		-0,117*		-0,158*		-0,080
Stručna literatura		-0,054		-0,064		-0,043
Radni status majke		0,004		-0,013		0,028
Radni status oca		-0,023		-0,038		-0,003
Materijalna dobra	0,027***		0,037**		0,037**	
Rod		-0,186***		–		–
Obrazovanje majke		0,173**		0,192**		0,164*
Obrazovanje oca		0,125*		0,156*		0,082
Klasična literatura		-0,093*		-0,113		-0,075
Stručna literatura		-0,042		-0,056		-0,028
Radni status majke		0,015		0,006		0,034
Radni status oca		-0,006		-0,048		0,053
Internet		-0,176***		-0,182**		-0,168*
Vlastiti stol		-0,014		0,080		-0,111
	$R^2 = 0,198$ ; Adj. $R^2 = 0,182$ ; $F(9/469) = 12,84$ , $p < 0,001$		$R^2 = 0,239$ ; Adj. $R^2 = 0,213$ $F(8/235) = 9,22$ , $p < 0,001$		$R^2 = 0,128$ Adj. $R^2 = 0,097$ ; $F(8/226) = 4,14$ , $p < 0,001$	

\*  $p < 0,05$ , \*\*  $p < 0,01$ , \*\*\*  $p < 0,001$

Rod je kodiran 1=ženski, 2=muški; obrazovanje oca i majke = veći rezultat ukazuje na viši stupanj obrazovanja; klasična i stručna literatura, te internet i vlastiti stol su kodirani 1=posjedujem, 2=ne posjedujem; radni status oca i majke 1=zaposlen/a, 2=nezaposlen/a ili umirovljenik/ca.



Odabrani prediktori objasnili su 18,2% varijance uspjeha iz matematike na cijelom uzorku, pri čemu je najviše varijance, 11,7% objašnjeno u drugom koraku pomoću obrazovanja roditelja. Blokovi prediktora s varijablama rod, posjedovanje literature te materijalna dobra objasnili su pojedinačno manje od 5% varijance ocjene iz matematike, dok blok s radnim statusom roditelja nije imao statistički značajan doprinos. U posljednjem koraku analize kao statistički značajni prediktori pokazali su se rod, obrazovanje majke i oca, posjedovanje klasične literature te pristup internetu. Učenice su imale bolji opći uspjeh od učenika. Kao što se i očekivalo, posjedovanje pristupa internetu i posjedovanje klasične literature te više obrazovanje roditelja predviđalo je bolji uspjeh iz matematike. Radni status majke i oca nisu se pokazali značajnim prediktorima, kao niti posjedovanje stručne literature i vlastitog stola za učenje.

Hijerarhijska regresijska analiza na uzorku učenica objasnila je 21,3% varijance uspjeha iz matematike, dok je na uzorku učenika istim prediktorima objašnjeno 9,7% varijance. Blok varijabli s obrazovanjem roditelja objasnio je najviše varijance kod obje skupine.

Kod učenica se više prediktora pokazalo statistički značajnima nego kod učenika. U prvom koraku su značajni prediktori matematičkog uspjeha učenica obrazovanje majke i oca, u drugom koraku značajnim prediktorom postaje posjedovanje klasične literature, dok se u trećem koraku radni status oca i majke nisu pokazali značajnima. U četvrtom koraku posjedovanje pristupa internetu postaje značajan prediktor, a posjedovanje klasične literature gubi statističku

značajnost što može upućivati na medijacijsku ulogu pristupa internetu u povezanosti posjedovanja klasične literature i matematičkog uspjeha učenica. U posljednjem koraku analize su od elemenata kulturnog kapitala značajni prediktori matematičkog uspjeha učenica bili obrazovanje oca i majke, a od elemenata ekonomskog kapitala samo posjedovanje pristupa internetu.

Kod učenika je model koji objašnjava njihov matematički uspjeh znatno jednostavniji. Obrazovanje majke i posjedovanje pristupa internetu bili su jedini statistički značajni prediktori pri čemu su više obrazovanje majke i pristup internetu predviđali bolji matematički uspjeh dječaka. Za razliku od djevojčica, kod dječaka ni obrazovanje oca ni posjedovanje klasične literature nisu bili značajni prediktori u objašnjenju uspjeha iz matematike.

S obzirom da odabir vrste srednje škole nije kontinuirana varijabla, predikciju biranja vrste srednje škole ispitali smo multinomijalnom logističkom regresijom. U logističkoj je regresiji kriterijska varijabla odabir vrste srednje škole: gimnazije, tehničke škole sa zastupljenijom matematikom i strukovne škole s manje zastupljenom matematikom. Kao prediktori su odabrani rod, obrazovanje roditelja, posjedovanje klasične i stručne literature, radni status majke, posjedovanje pristupa internetu i posjedovanje vlastitog stola za učenje. Radni status oca i posjedovanje satelitske televizije izostavljeni su iz logističke regresije jer u hi-kvadrat testovima nisu imali statistički značajan efekt na odabir vrste srednje škole. Rezultati logističke regresije prikazani su u tablici 4.

Tablica 4.

*Rezultati multinomijalne logističke regresije za objašnjenje odabira vrste srednje škole (N=467)*

Usporedba šansi odabira strukovnih škola s manje zastupljenom matematikom i gimnazije		
	B	Exp(B)
Ocjena iz matematike	1,404***	4,071
Rod		
Ženski	-0,330	0,719
Muški	0,000	.
Obrazovanje roditelja		
Osnovna škola	-2,147	0,117
Srednja škola	-1,247***	0,287
Fakultet i viša škola	0,000	.
Internet		
Ima	0,874	2,395
Nema	0,000	.
Klasična literatura		
Ima	0,902*	2,465
Nema	0,000	.
Stručna literatura		
Ima	-0,231	0,794
Nema	0,000	.
Vlastiti stol		
Ima	0,955	2,598
Nema	0,000	.
Radni status majke		
Zaposlena	-0,124	0,883
Nezaposlena	0,000	.
Konstanta	-6,071***	
Usporedba šansi odabira strukovnih škola s manje zastupljenom matematikom i tehničkih škola sa zastupljenijom matematikom		
	B	Exp(B)
Ocjena iz matematike	0,564**	1,758
Rod		
Ženski	-3,188***	0,041
Muški	0,000	.
Obrazovanje roditelja		
Osnovna škola	-0,520	0,594
Srednja škola	0,148	1,160
Fakultet i viša škola	0,000	.
Internet		
Ima	1,259	3,522
Nema	0,000	.
Klasična literatura		
Ima	0,303	1,354
Nema	0,000	.
Stručna literatura		
Ima	0,527	1,695
Nema	0,000	.
Vlastiti stol		
Ima	0,717	2,049
Nema	0,000	.
Radni status majke		
Zaposlena	-0,936*	0,392
Nezaposlena	0,000	.
Konstanta	4,088**	
Pseudo R <sup>2</sup> (Cox i Snell; Nagelkerke; McFadden) <sup>6</sup>	0,482; 0,572; 0,356	
-2 Log L	268,499	

\* p&lt;0,05, \*\* p&lt;0,01, \*\*\* p&lt;0,001

Referentna kategorija su strukovne škole s manje zastupljenom matematikom (1=gimnazije; 2=tehničke škole sa zastupljenijom matematikom; 3=strukovne škole s manje zastupljenom matematikom).

B = koeficijent logističke funkcije; Exp B = relativna šansa nekog ishoda.

<sup>6</sup> U logističkoj regresiji postoji nekoliko mjera koje su analogne R<sup>2</sup> u multiploj linearnoj regresijskoj analizi. Budući da logistička regresija nije zasnovana na konceptu varijance, ove »pseudo« mjere poput Cox i Snell R<sup>2</sup>, Nagelkerke R<sup>2</sup> i McFadden R<sup>2</sup>, imaju više deskriptivnu ulogu (Tabachnik i Fidell, 2007.).

Kada se analiziraju čimbenici koji objašnjavaju hoće li učenik/ca upisati gimnaziju ili strukovnu školu s manjom satnicom nastave matematike, kao značajni prediktori pokazali su se ocjena iz matematike, obrazovanje roditelja i posjedovanje klasične literature. Nakon kontrole ostalih prediktora, veću šansu odabira gimnazije u odnosu na strukovne škole s manjom satnicom matematike imali su učenici/e boljih ocjena iz matematike, zatim učenici/e čiji je barem jedan roditelj završio visoko/više obrazovanje, a ne srednjoškolsko obrazovanje, te učenici/e koji imaju klasičnu literaturu kod kuće.

Kada se analiziraju čimbenici koji objašnjavaju hoće li učenik/ca upisati tehničku školu sa zastupljenijom matematikom ili strukovne škole s manjom satnicom matematike, kao značajni prediktori pokazali su se ocjena iz matematike, rod i radni status majke, no ovaj posljednji prediktor je marginalno značajan. Nakon kontrole ostalih prediktora, veću šansu odabira tehničke škole sa zastupljenijom matematikom u odnosu na ostale strukovne škole imali su učenici/e boljih ocjena iz matematike, dječaci a ne djevojčice, te učenici/e čija je majka nezaposlena.

## RASPRAVA

Cilj rada bio je ispitati povezanost roda i socioekonomskih i sociokulturnih obilježja učenika/ca s njihovim uspjehom iz matematike, kao i s njihovim odabirom srednje škole prema zastupljenosti matematike.

Ispitivanje pojedinačnih efekata indikatora ekonomskog i kulturnog kapitala učenika/ca na njihov školski uspjeh iz matematike i odabir srednje škole potvrdilo je pretpostavku da učenici/ce iz obitelji višeg socioekonomskog i sociokulturnog statusa postižu u prosjeku bolji uspjeh iz matematike, kao i da češće biraju srednje škole sa

zastupljenijom matematikom od učenika/ca nižeg statusa. Takav nalaz ne iznenađuje jer je riječ o gimnazijama i prestižnijim tehničkim školama koje bolje od drugih škola omogućuju stjecanje obrazovnih pretpostavki za nastavak obrazovanja na fakultetima i zapošljavanje u ekonomski atraktivnim i uglednim zanimanjima. Prema očekivanjima, pokazalo se da su obrazovanje roditelja i posjedovanje klasične i/ili stručne literature (indikator kulturnog kapitala) pozitivno povezani s ocjenom iz matematike. Ovi nalazi u skladu su s rezultatima studije u kojoj se obiteljsko posjedovanje knjiga i drugih kulturnih dobara pokazalo značajno povezanom s matematičkom kompetencijom ispitanih učenika/ca (Jungbauer-Gans, 2006.) te s rezultatima istraživanja koja su pokazala važnost obrazovanja roditelja za uspjeh iz matematike (White, 1982.; Sirin, 2005.). Ako obrazovanje roditelja i posjedovanje kulturnih dobara promatramo primarno kao obiteljske kulturne resurse, njihov se značaj za matematička postignuća može objasniti specifičnim socijalizacijskim okruženjem koje stimulira učenje, a čije su vrijednosti i sadržaji bliski školskoj kulturi i očekivanjima nastavnika (Bourdieu, 1977.; Lareau i Weininger, 2003.).

S obzirom na to da stjecanje kulturnog kapitala pretpostavlja određenu »distanciranost od ekonomske nužnosti« (Bourdieu, 1997.), do akumulacije kulturnog kapitala najčešće dolazi u obiteljima koje pored kulturnih resursa učenicima/cama osiguravaju i materijalne uvjete i resurse potrebne za obavljanje svakodnevnih zadataka vezanih uz školu. Sukladno tome, naši rezultati pokazali su da se ocjene učenika/ca iz matematike, osim prema kulturnom kapitalu, razlikuju i prema većini ispitivanih indikatora ekonomskog kapitala, pri čemu su posjedovanje vlastitog stola za učenje, posjedovanje pristupa internetu i radni sta-

tus majke i oca povezani s boljom ocjenom iz matematike. Ovakav je rezultat na tragu niza srodnih studija u kojima je utvrđena pozitivna korelacija između obiteljskog SES-a i uspjeha iz matematike (White, 1982.; Tate, 1997.; Sirin, 2005.). Rezultati prema kojima učenici/ce s više ekonomskog kapitala imaju bolju ocjenu iz matematike također odgovaraju rezultatima hrvatskog PISA istraživanja koji pokazuju da učenici/e iz obitelji s višim međunarodnim indeksom zaposlenja (HISEI) te višim indeksom ekonomskog, društvenog i kulturnog statusa (ESCS) imaju i bolji rezultat iz matematičke pismenosti (Braš Roth i sur., 2008.).

Vezano uz razlike u odabiru srednje škole rezultati našeg istraživanja pokazali su da učenici/ce s više kulturnog i ekonomskog kapitala imaju veću šansu odabrati srednje škole sa zastupljenijom matematikom u odnosu na učenike/ce iz obitelji nižeg statusa. Pritom se važnost kulturnog kapitala za ovakav odabir može objasniti akademski poticajnim obiteljskim okruženjem, kao i činjenicom da i obrazovne aspiracije učenika/ca i roditelja rastu s obiteljskim statusom (Baumert i Schümer, 2001.; Dumais, 2002.). Povezanost boljih ekonomskih resursa s odabirom prestižnijih škola sa zastupljenijom matematikom objašnjavamo obrazovnim preferencijama učenika/ca i roditelja koje se orijentiraju prema očekivanoj dobiti od produljenog obrazovanja kao i prema činjenici da matematika postaje sve važnija za pristup privilegiranim segmentima tržišta rada (Goldthorpe, 1996.; Carnevale i Desrochers, 2003.).

Podaci našeg istraživanja također potvrđuju pretpostavku da učenice u prosjeku postižu bolji uspjeh iz matematike od učenika te da više učenica nego učenika planira upisati gimnaziju, dok učenici češće nego učenice biraju tehničke škole sa zastupljenijom matematikom. Nalaz prema

kojemu učenice imaju statistički značajno bolje ocjene iz matematike od učenika sukladan je postojećim istraživanjima u kojima se ističe da su djevojčice razmjerno uspješnije od dječaka kada se postignuće iz matematike iskazuje školskim ocjenama na osnovnoškolskoj i srednjoškolskoj razini (Hart Reyes i Stanic, 1988.). Lošije ocjene dječaka objašnjavaju se pritom i razlikama u rodnoj socijalizaciji, odnosno konstrukciji rodnih identiteta, pri čemu se kod dječaka razvija uvjerenje da trebaju postizati školski uspjeh bez ulaganja truda u učenje (Jackson i Dempster, 2009.), dok je kod djevojčica postizanje boljeg školskog uspjeha dio konstrukcije femininosti (Walkerline i sur., 2001.). Nalaz da učenice češće biraju gimnazije, a učenici tehničke škole može se objasniti s jedne strane važnošću ocjena pri upisu u gimnazije, a s druge rodnim stereotipima vezanim uz područje tehničkih znanosti. Pretpostavka o stereotipima odgovara službenim statističkim podacima koji svjedoče o rodnoj dihotomizaciji pojedinih strukovnih područja u hrvatskom srednjoškolskom obrazovanju, posebno u području tehničkih znanosti u kojemu je poznavanje matematike od velike važnosti (Državni zavod za statistiku, 2012.). Kao moguće objašnjenje rodne dihotomizacije u literaturi se navodi nesklad između ženske rodne uloge i predodžbe o matematici i tehnicima kao muškoj domeni, koji se pojavljuje u adolescentskoj dobi (npr. uslijed pojačanog rodnog stereotipiziranja vršnjačkih grupa) i zbog kojeg djevojčice počinju gubiti interes za tehničke predmete i matematiku (Massey, 1995.; Wiest, 2011.).

Jedan od ciljeva istraživanja bio je ispitati koji od spomenutih indikatora sociokulturnog i socioekonomskog statusa obitelji učenika/ca najbolje predviđaju uspjeh iz matematike. Rezultati provedene hijerarhijske regresijske analize pokazuju da testirani model na cijelom uzorku objašnjava

ukupno 18% varijance ocjene iz matematike čemu je najviše doprinijelo obrazovanje roditelja i to posebno obrazovanje majke. Iznos objašnjene varijance uspjeha iz matematike veći je od postotka koji, na osnovi usporedivog modela, navode De Graaf (1988.) (7%) i DiMaggio (1982.) (7-9%), a manji od vrijednosti koju navodi Jungbauer-Gans (2006.) (26%). Pored obrazovanja majke i oca, u zadnjem koraku analize statistički značajan doprinos objašnjenju uspjeha iz matematike dali su rod, posjedovanje klasične literature i posjedovanje pristupa internetu. Usporedba pojedinih blokova prediktora u našoj analizi pokazuje da uvođenje indikatora kulturnog i ekonomskog kapitala u regresijski model ne smanjuje beta koeficijente roda čiji efekt na ocjenu iz matematike ostaje stabilan. Nalaz da su obrazovanje roditelja i posjedovanje kulturnih dobara statistički značajni prediktori ocjene iz matematike sukladan je Bourdieuovoj (1997.) pretpostavci o nezavisnom utjecaju različitih oblika kulturnog kapitala na obrazovna postignuća. S druge strane, podatak da je posjedovanje pristupa internetu značajan prediktor ocjene iz matematike potvrđuje da je uspjeh iz matematike povezan i sa socioekonomskim statusom obitelji učenika, odnosno posjedovanjem obrazovnih resursa (Crane, 1996.).

Hijerarhijske regresijske analize na zasebnim uzorcima učenica i učenika znatno se razlikuju s obzirom na postotak objašnjene varijance ocjene iz matematike. Kod učenica je ovaj postotak znatno veći. Rodne su razlike osobito vidljive kada je riječ o kulturnom kapitalu čiji su efekti veći kod djevojčica nego dječaka. Za razliku od učenika kod kojih se značajnim prediktorom pokazalo samo obrazovanje majke, na uzorku učenica statistički značajnima su se pokazali još i obrazovanje oca i posjedovanje klasične literature. Ovakav rezultat potvrđuje nalaz Dumais (2002.) koja, na osnovi

analize uzorka američkih srednjoškolaca, zaključuje da kulturni kapital u većoj mjeri doprinosi obrazovnom uspjehu djevojčica nego dječaka. Kao moguće objašnjenje autorica navodi da posjedovanje kulturnog kapitala učenicama pomaže u povećanju njihove »vidljivosti« u razredu u kojem je pažnja nastavnika u pravilu više usmjerena dječacima nego djevojčicama. Ili preciznije, učenicama kulturni kapital pomaže u stjecanju akademskog samopouzdanja i sigurnosti čime se potiče njihova asertivnost u razredu. Nasuprot tome, dječaci češće umanjuju ili prikrivaju svoj kulturni kapital (npr. interes za ples ili kazalište) budući da ga vide bliže rodnom identitetu djevojčica. Nalazi hijerarhijske regresijske analize prema kojima kod učenica obrazovanje majke ima veći efekt na matematičko postignuće od obrazovanja oca, dok se kod učenika samo obrazovanje majke, ali ne i oca, pokazuje statistički značajnim prediktorom uspjeha iz matematike, može se objasniti tradicionalno većom ulogom majke od očeva u odgoju djece.

Koliko rod, obiteljsko podrijetlo učenika/ca te uspjeh iz matematike predviđaju odabir srednje škole s većom ili manjom zastupljenošću matematike pokazuju rezultati multinomijalne regresijske analize. Usporedbom šansi odabira između gimnazije i strukovnih škola s manjom zastupljenošću matematike te između tehničkih škola sa zastupljenijom matematikom i strukovnih škola s manjom satnicom matematike, pokazuje se da i u jednom i u drugom slučaju ocjena iz matematike predstavlja najsnažniji prediktor odabira srednje škole. Ovakav nalaz odgovara rezultatima istraživanja u drugim zemljama prema kojima obrazovna postignuća učenika/ca imaju jači efekt na odabir srednje škole u usporedbi s kontekstualnim varijablama (De Graaf, 1988.; Meier Jaeger, 2009.). No, primjetne su i razlike između dvaju tipova obrazovnih



izbora u našem istraživanju. Kada se kontrolira efekt ocjene iz matematike, odabir gimnazije prvenstveno je povezan s kulturnim resursima obitelji učenika/ca, dok je odabir tehničke škole više povezan s njihovim rodom i, u manjoj mjeri, sa socioekonomskim statusom obitelji. Nalaz da je uz ocjenu iz matematike, gimnazijski odabir učenika/ca u Hrvatskoj povezan s različitim oblicima kulturnog kapitala sukladan je rezultatima istraživanja iz drugih zemalja (De Graaf, 1988.; Meier Jaeger, 2009.; Flere, 2010.). Meier Jaeger (2009.) ovakav nalaz objašnjava rastućom vrijednošću kulturnog kapitala u formalno meritokratskom danskom obrazovnom okruženju u kojem raspolaganje kulturnim resursima sve više zamjenjuje tradicionalne obrasce isključivanja na osnovi ekonomskih nejednakosti. S druge strane, nalaz da je odabir tehničkih škola s više matematike povezan prvenstveno s rodom učenika/ca ukazuje na, barem kada je riječ o ovome specifičnom tipu srednje škole, prisutnost stereotipnih odabira srednjih škola.

Zaključno, istraživanje upućuje da školski uspjeh iz matematike diferencira učenike/ce s obzirom na rod te ekonomske i kulturne resurse njihovih obitelji. Kako je riječ o istraživanju učenika/ca 8. razreda, rezultati upozoravaju da se društvena diferencijacija učenika/ca zbiva već na razini obaveznog školovanja, pri čemu matematika uz druge faktore služi kao jedno od relevantnih sredstava i socijalne i obrazovne selekcije učenika/ca. Naime, ocjena iz matematike spada među važnije uvjete koji utječu na izbor srednje škole o čemu ovisi daljnji obrazovni i profesionalni put, a time i društveno pozicioniranje pojedinca. Navedeni nalazi predstavljaju važnu znanstvenu podlogu za kreiranje političkih odluka u cilju smanjenja društvenih i obrazovnih nejednakosti u obaveznom obrazovanju. Oni upućuju na potrebu usmjerava-

nja obrazovne politike na osvješćivanje i senzibiliziranje škola za problem povezanosti uspjeha iz matematike s ekonomskim i kulturnim resursima obitelji učenika/ca. U tom kontekstu, važno je naglasiti potrebu za poticanjem škola na osmišljavanje i provođenje školskih aktivnosti koje mogu doprinijeti intenziviranju i prilagodbi nastave matematike za učenike iz obitelji koje im ne mogu pružiti obrazovnu potporu za postizanje boljeg uspjeha iz matematike. Osiguranje kadrovskih i materijalnih pretpostavki za provođenje spomenutih aktivnosti zahtijeva sinergijsko djelovanje škola i ostalih ključnih aktera u području obrazovanja (npr. predstavnika obrazovne politike, obrazovnih agencija, nastavnčkih i učiteljskih fakulteta).

Istraživanje je teorijski relevantno jer predstavlja jedno od prvih empirijskih istraživanja u Hrvatskoj fokusiranih na ispitivanje društvenih karakteristika uspjeha učenika/ca iz matematike, tj. povezanosti socioekonomskih i sociokulturnih karakteristika učenika/ca i njihovog uspjeha iz matematike. Provođenje i rezultati istraživanja ukazali su i na njegova metodološka ograničenja. Ona prije svega proizlaze iz ograničenosti uzorka istraživanja na učenike/ce osnovnih škola iz Zagreba i Zagrebačke županije uslijed čega nalazi istraživanja nisu reprezentativni na nacionalnoj razini. Metodološka ograničenja istraživanja također su bila uvjetovana i s dobi ispitanika/ca. Budući da je istraživanje provedeno na 14-godišnjacima, pri konstrukciji upitnika mogla su se navoditi pitanja koja su razumljiva i primjerena njihovoj dobi, što u konačnici ograničava operacionalizaciju korištenih teorijskih koncepata. Tako se npr. u pitanju o obiteljskom posjedovanju klasične i stručne literature učenike pitalo imaju li ili ne određene vrste knjiga, ali ne i koji broj knjiga posjeduju, što bi dalo precizniji uvid. Također se pokazalo da ispitanici/ce

imaju poteškoće s poznavanjem zanimanja i školovanja svojih roditelja što može predstavljati poteškoću za dobivanje pouzdanih odgovora na ta pitanja. Spomenuta ograničenja upućuju na potrebu korištenja navedenih iskustava u konstrukciji istraživačkih instrumenata u narednim istraživanjima, dok ograničenost uzorka na Grad Zagreb i Zagrebačku županiju ukazuje na potrebu širenja empirijskog istraživanja ove problematike na nacionalnu razinu.

## LITERATURA

- Apple, Michael W. (1992). Do the standards go far enough? Power, policy, and practice in mathematics education. *Journal for Research in Mathematics Education*, 23(5), 412-431. doi: 10.2307/749562
- Arambašić, L., Vlahović-Štetić, V., & Severinac, A. (2005). Je li matematika bauk? Stavovi, uvjerenja i strah od matematike kod gimnazijalaca. *Društvena istraživanja*, 14(6), 1081-1102. Dostupno na <http://hrcak.srce.hr/file/28166>
- Baranović, B. (2011). Percepcija, iskustvo i stavovi o rodnoj (ne)ravnopravnosti u obrazovanju. U Ž. Kamenov & B. Galić (ur.), *Rodna ravnopravnost i diskriminacija u Hrvatskoj: Istraživanje „Percepcija, iskustva i stavovi o rodnoj diskriminaciji u Republici Hrvatskoj“* (str. 38-48). Zagreb: Ured za ravnopravnost spolova Vlade RH.
- Baumert, J., & Schümer, G. (2001). Familiäre Lebensverhältnisse, Bildungsbeteiligung und Kompetenzerwerb. In Deutsches PISA-Konsortium (Eds.), *PISA 2000: Basiskompetenzen von Schülerinnen und Schülern im internationalen Vergleich* (pp. 323-407). Opladen: Leske und Budrich.
- Bishop, A. J., & Forgasz, H. J. (2007). Issues in access and equity in mathematics education. In F. K. Lester Jr. (Ed.), *Second handbook of research on mathematics teaching and learning* (pp. 1145-1167). Charlotte: Information Age Publishing.
- Bourdieu, P. (1977). Cultural reproduction and social reproduction. In J. Karabel & A. H. Halsey (Eds.), *Power and ideology in education* (pp. 487-511). New York: Oxford University Press.
- Bourdieu, P. (1996). *The state nobility*. Cambridge: Polity Press.
- Bourdieu, P. (1997). The forms of capital. In A. H. Halsey, H. Lauder, P. Brown & A. Stuart Wells (Eds.), *Education: Culture, economy, and society* (pp. 47-58). Oxford: Oxford University Press.
- Braš Roth, M., Gregurović, M., Markočić Dekanić, A., & Markuš, M. (2008). *PISA 2006 - Prirodoslovne kompetencije za život*. Zagreb: Nacionalni centar za vanjsko vrednovanje obrazovanja.
- Braš Roth, M., Markočić Dekanić, A., Markuš, M., & Gregurović, M. (2010). *PISA 2009 - Čitalačke kompetencije za život*. Zagreb: Nacionalni centar za vanjsko vrednovanje obrazovanja.
- Carnevale, A. P., & Desrochers, D. M. (2003). The democratization of mathematics. In B. L. Madison & L. A. Steen (Eds.), *Quantitative literacy: Why numeracy matters for schools and colleges* (pp. 21-31). Princeton: The National Council on Education and the Disciplines. Available at [https://www.maa.org/external\\_archive/QL/pgs21\\_31.pdf](https://www.maa.org/external_archive/QL/pgs21_31.pdf)
- Crane, J. (1996). Effects of home environment, SES, and maternal test scores on mathematics achievement. *The Journal of Educational Research*, 89(5), 305-314. doi: 10.1080/00220671.1996.9941332
- Cvitan, M., Doolan, K., Farnell, T., & Matković, T. (2011). *Socijalna i ekonomska slika studentskog života u Hrvatskoj: nacionalno izvješće istraživanja EUROSTUDENT za Hrvatsku*. Zagreb: Institut za razvoj obrazovanja.
- De Graaf, P. M. (1988). Parent's financial and cultural resources, grades, and transition to secondary school in the Federal Republic of Germany. *European Sociological Review*, 4(3), 209-221.
- DiMaggio, P. (1982). Cultural capital and school success: The impact of status culture participation on the grades of U.S. high school students. *American Sociological Review*, 47(2), 189-201. doi: 10.2307/2094962
- Državni zavod za statistiku. (2008). Srednje škole i učenički domovi. *Statistička izvješća*, br. 1359. Zagreb: DZS.

- Državni zavod za statistiku. (2012). *Žene i muškarci u Hrvatskoj 2012*. Dostupno na [http://www.dzs.hr/Hrv/publication/men\\_and\\_women.htm](http://www.dzs.hr/Hrv/publication/men_and_women.htm)
- Dumais, S. (2002). Cultural capital, gender, and school success: The role of habitus. *Sociology of Education*, 75(1), 44-68. doi: 10.2307/3090253
- Eccles, J. S. (1994). Understanding women's educational and occupational choices: Applying the Eccles et al. model of achievement-related choices. *Psychology of Women Quarterly*, 18(4), 585-609. doi: 10.1111/j.1471-6402.1994.tb01049.x
- Eccles, J. S., Wigfield, A., Harold, R. D., & Blumenfeld, P. (1993). Age and gender differences in children's self- and task perceptions during elementary school. *Child Development*, 64(3), 830-847. doi: 10.2307/1131221
- Farmer, H. S., Wardrop, J. L., Anderson, M. Z., & Risinger, R. (1995). Women's career choices: Focus on science, math, and technology careers. *Journal of Counseling Psychology*, 42(2), 155-170. doi: 10.1037/0022-0167.42.2.155
- Flore, S., Tavčar Krajnc, M., Klanjšek, R., Mušil, B., & Kirbiš, A. (2010). Cultural capital and intellectual ability as predictors of scholastic achievement: A study of Slovenian secondary school students. *British Journal of Sociology of Education*, 31(1), 47-58. doi: 10.1080/01425690903385428
- Goldthorpe, J. H. (1996). Class analysis and the reorientation of class theory: The case of persisting differentials in educational attainment. *The British Journal of Sociology*, 47(3), 481-505. doi: 10.2307/591365
- Hart Reyes, L., & Stanic, G. M. A. (1988). Race, sex, socioeconomic status, and mathematics. *Journal for Research in Mathematics Education*, 19(1), 26-43. doi: 10.2307/749109
- Hyde, J. S., Fennema, E., & Lamon, S. J. (1990). Gender differences in mathematical performance: A meta-analysis. *Psychological Bulletin*, 107(2), 139-155. doi: 10.1037/0033-2909.107.2.139
- Hyde, J. S., Fennema, E., Ryan, M., Frost, L. A., & Hopp, C. (1990). Gender comparisons of mathematics attitudes and affect: A meta-analysis. *Psychology of Women Quarterly*, 14(3), 299-324. doi: 10.1111/j.1471-6402.1990.tb00022.x
- Hyde, J. S., Lindberg, S. M., Linn, M. C., Ellis, A. B., & Williams, C. E. (2008). Gender similarities characterize math performance. *Science*, 327(5888), 494-495. doi: 10.1126/science.1160364
- Jackson, J., & Dempster, S. (2009). 'I sat back on my computer ... with a bottle of whisky next to me': constructing 'cool' masculinity through 'effortless' achievement in secondary and higher education. *Journal of Gender Studies*, 18(4), 341-356. doi: 10.1080/09589230903260019
- Jacobs, J., & Eccles, J. S. (1992). The impact of mothers' gender-role stereotypic beliefs on mothers' and children's ability perceptions. *Journal of Personality and Social Psychology*, 63(6), 932-944. doi: 10.1037/0022-3514.63.6.932
- Jokić, B., & Ristić Dedić, Z. (2010). Razlike u školskom uspjehu učenika trećih i sedmih razreda osnovnih škola u Republici Hrvatskoj s obzirom na spol učenika i obrazovanje roditelja: populacijska perspektiva. *Revija za socijalnu politiku*, 17(3), 345-362. doi: 10.3935/rsp.v17i3.954
- Jugović, I., Baranović, B., & Marušić, I. (2012). Uloga rodni stereotipa i motivacije u objašnjenju matematičkog uspjeha i straha od matematike. *Suvremena psihologija*, 15(1), 65-79. Dostupno na <http://hrcak.srce.hr/file/126127>
- Jungbauer-Gans, M. (2006). Kulturelles Kapital und Mathematikleistungen – eine Analyse der PISA 2003 – Daten für Deutschland. In W. Georg (Ed.), *Soziale Ungleichheit im Bildungssystem. Eine empirisch-theoretische Bestandsaufnahme* (pp. 175-198). Konstanz: UVK.
- Karabel, J., & Halsey, A. H. (1977). Educational research: A review and an interpretation. In J. Karabel & A. H. Halsey (Eds.), *Power and ideology in education* (pp. 1-85). New York: Oxford University Press.
- Lareau, A., & Weininger, E. B. (2003). Cultural capital in educational research: A critical assessment. *Theory and Society*, 32(5-6), 567-606. doi: 10.1023/B:RYSO.0000004951.04408.b0

- Lindberg, S. M., Hyde, J. S., Petersen, J. L., & Linn, M. C. (2010). New trends in gender and mathematics performance: A meta-analysis. *Psychological Bulletin*, 136(6), 1123-1135. doi: 10.1037/a0021276
- Lubienski, S. T. (2008). On »Gap gazing« in mathematics education: The need for gaps analysis. *Journal for Research in Mathematics Education*, 39(4), 350-356. Dostupno na <http://www.jstor.org/stable/40539301>
- Lupart, J. L., Cannon, E., & Telfer, J. A. (2004). Gender differences in adolescent academic achievement, interests, values and life-role expectations. *High Ability Studies*, 15(1), 25-42. doi: 10.1080/1359813042000225320
- Organisation for Economic Co-operation and Development. (2004). *Learning for tomorrow's world. First results from PISA 2003*. Paris: OECD.
- Organisation for Economic Co-operation and Development. (2007). *PISA 2006. Volume 2: Data/Données*. Paris: OECD.
- Marušić, I. (2006). Motivacija i školski predmeti: spolne razlike među učenicima u kontekstu teorije vrijednosti i očekivanja. U B. Baranović (ur.), *Nacionalni kurikulum za obvezno obrazovanje u Hrvatskoj - različite perspektive* (str. 219-257). Zagreb: Institut za društvena istraživanja.
- Massey, D. (1995). Masculinity, dualism and high technology. *Transactions of the Institute of British Geographers*, 20(4), 487-499. doi: 10.2307/622978
- Meier Jæger, M. (2009). Equal access but unequal outcomes: Cultural capital and educational choice in a meritocratic society. *Social Forces*, 87(4), 1943-72. doi: 10.1353/sof.0.0192
- Moreau, M. P., Osgood, J., & Halsall, A. (2008). Policies in English schools: Towards greater gender equality in the teaching workforce?. *Gender, Work and Organization*, 15(6), 553-578. doi: 10.1111/j.1468-0432.2008.00405.x
- Mullis, I. V. S., Martin, M. O., Gonzales, E. J., & Chrostowski, S. J. (2004). *TIMSS 2003 International Mathematics Report. Findings from IEA's International and Science Study at the fourth and eighth grades*. Chestnut Hill, MA: Boston College.
- Popkewitz, T. S. (1988). Institutional issues in the study of school mathematics. *Educational Studies in Mathematics*, 19(2), 221-249. doi: 10.1007/BF00751234
- Puzić, S., & Baranović, B. (2012). Društveni aspekti matematičkog obrazovanja. *Revija za sociologiju*, 42(2), 161-186. doi: 10.5613/rzs.42.2.3
- Scafidi, T., & Bui, K. (2010). Gender similarities in math performance from middle school through high school. *Journal of Instructional Psychology*, 37(3), 252-255.
- Sirin, S. R. (2005). Socioeconomic status and academic achievement: A meta-analytic review of research. *Review of Educational Research*, 75(3), 417-453. doi: 10.3102/00346543075003417
- Sullivan, A. (2001). Cultural capital and educational attainment. *Sociology*, 35(4), 893-912. doi: 10.1177/0038038501035004006
- Tabachnik, B. G., & Fidell, L. S. (2007). *Using multivariate statistics*. London: Pearson.
- Tate, W. F. (1997). Race-ethnicity, SES, gender, and language proficiency trends in mathematics achievement: An update. *Journal for Research in Mathematics Education*, 28(6), 652-679. doi: 10.2307/749636
- Walkerdine, V., Lucey, H., & Melody, J. (2001). Growing up girl: Psychosocial explorations of gender and class. Basingstoke: Palgrave.
- White, K. R. (1982). The relation between socioeconomic status and academic achievement. *Psychological Bulletin*, 91(3), 461-481. doi: 10.1037/0033-2909.91.3.461
- Wiest, L. R. (2011). Females in mathematics: Still on the road to parity. In B. Atweh, M. Grawen, W. Secada & P. Valero (Eds.), *Mapping equity and quality in mathematics education* (pp. 325-339). New York: Springer.

### Summary

## ***THE IMPORTANCE OF FAMILY BACKGROUND AND GENDER FOR MATHEMATICS ACHIEVEMENT AND SECONDARY SCHOOL CHOICE***

***Branislava Baranović***

***Ivana Jugović***

***Saša Puzić***

*Institute for Social Research in Zagreb  
Zagreb, Croatia*

*The article presents the research results on the effects that gender and socio-economic and socio-cultural characteristics have on pupils' achievement in mathematics and secondary school choice. The research was conceptually connected to Bourdieu (1977) and carried out on a sample of 693 elementary school pupils from Zagreb and the surrounding Zagreb County.*

*The results have shown that girls have higher school grades in mathematics than boys, and are more likely to choose grammar schools than vocational schools with a large number of math lessons (technical schools). Pupils from families with higher socio-economic and socio-cultural status achieve better grades and more often choose schools with a large number of math lessons. Gender, parents' higher level of education, owning classical literature and the Internet access in one's home proved to be the strongest predictors of higher mathematics achievement. As for the choice of schools, the choice of grammar school was primarily explained by cultural resources of the family, while the choice of technical school was explained by pupils' gender. These findings are consistent with the results of similar research studies in other countries.*

**Key words:** socio-economic status, socio-cultural status, eighth grade pupils, achievement in mathematics, secondary school choice.